

微生物图像的非局部主成分分析稀疏泊松去噪

孙照旋,周芳,朱志峰

(安徽工业大学 电气与信息工程学院,安徽 马鞍山 243032)

摘要:针对微生物显微图像去噪,提出一种基于图像稀疏块表示和字典学习的泊松去噪算法。根据微生物图像内在相关性进行分块处理,采用Poisson K -均值法对图像块进行聚类;运用主成分分析法实现非局部稀疏字典表示,完成簇内去噪;经融合重建,获得完整去噪图像。结果表明:通过稀疏块表示和字典学习直接对泊松噪声去噪,可减少噪声模型转换误差;改进的分块和聚类方法可提高去噪图像的信噪比;与其他去噪算法对比,本文算法不仅取得更好的去噪效果,且可改善去噪后图像模糊现象,最大程度地保留图像细节信息。

关键词:微生物;图像去噪;主成分分析;稀疏表示;Poisson K -均值聚类

中图分类号:TN 919.82 **文献标志码:**A **doi:**10.3969/j.issn.1671-7872.2021.01.012

Sparse Poisson Denoising of Microbial Images Based on Non-local Principal Component Analysis

SUN Zhaoxuan, ZHOU Fang, ZHU Zhifeng

(School of Electrical and Information Engineering, Anhui University of Technology, Maanshan 243032, China)

Abstract: For the denoising of micro image of microorganism, a Poisson denoising algorithm based on image sparse block representation and dictionary learning was proposed. Firstly, according to the intrinsic correlation of microbial images, the image blocks were clustered by Poisson K -means method; Secondly, the non-local sparse dictionary representation was realized by principal component analysis to complete the intra cluster denoising; Finally, the complete denoised image was obtained by fusion reconstruction. The results show that through sparse block representation and dictionary learning, Poisson can be denoised directly, which can reduce the error of noise model transformation; The improved block and clustering methods can greatly improve the signal-to-noise ratio of denoised image. Compared with other denoising algorithms, the proposed method not only achieves better denoising effect, but also significantly improves the image blur quality, and retains more image details to the maximum extent.

Key words: microorganism; image denoising; principal component analysis; sparse representation; Poisson K -means clustering

图像处理有去噪、分割^[1]、检测和识别等过程,去噪是图像处理的经典问题之一。在显微图像的成像系统中,可用光数量有限、光子受限给图像对比度带来不利影响。图像噪声多服从于泊松分布,故称图像噪声为泊松噪声。简单将泊松噪声数据转换为近似高斯噪声数据,如小波收缩法^[2]、方差稳定变换(variance stabilize transformation, VST)^[3]等可在低噪声情况下达到有效去噪效果,但在高噪声情况下,这些方法的去噪效果不

收稿日期:2020-08-25

基金项目:国家自然科学基金项目(61601004);安徽省质量工程项目(2019jyxm1181);安徽省自然科学基金项目(608085MA05)

作者简介:孙照旋(1996—),女,安徽滁州人,硕士生,主要研究方向为数字图像处理与模式识别。

通信作者:周芳(1977—),女,安徽芜湖人,博士,副教授,主要研究方向为数字图像处理与模式识别。

引文格式:孙照旋,周芳,朱志峰.微生物图像的非局部主成分分析稀疏泊松去噪[J].安徽工业大学学报(自然科学版),2021,38(1):82-89.

好。Zhang等^[3]提出一种基于卷积神经网络的泊松去噪模型,称该网络为方差稳定变换网络,整个网络包含三个子网。第一和第三个子网分别模拟正向和反向 Anscombe 变换,第二个子网络近似于高斯去噪。该模型克服了传统 VST 去噪过平滑的缺点,取得了较好的去噪效果,但在噪声等级较高时,去噪效果仍不太理想,图像易模糊且算法复杂度高。

图像非局部去噪方法不同于传统基于局部邻域像素级去噪方法,如非局部均值法(nonlocal means, NLM)^[4-5]和非局部正则化法^[6-7],其不仅能够有效提高运算速度,还能够更多保持图像几何结构特征。汪浩然等^[8]引入主成分分析(principal component analysis, PCA),把像素点及其邻域看作一个目标像素块进行整体去噪,较好地保护了图像局部细节信息。Xu等^[9]运用字典学习算法对混合噪声去噪,取得了较好的效果,但只能针对真实自然图像中的噪声,对显微图像或含不同噪声级的泊松噪声图像,去噪效果不理想。印佳等^[10]提出基于主成分分析的高光谱遥感图像非局部去噪方法,根据高光谱图像本身和噪声特征,研究基于 PCA 的非局部去噪方法,充分利用光谱的谱间相似性和谱内相似性,通过 PCA 降维选择代表性信号维度,对于这些维度运用非局部的 BM3D (block-matching and 3D filtering) 法去除噪声,得到了较好的去噪效果,但该方法也只能对高斯白噪声进行去噪。因此,根据显微图像的泊松噪声结构模型以及污水微生物目标纹理细节丰富的特征,结合非局部和主成分分析方法,提出一种基于图像分块聚类的非局部 PCA 稀疏泊松去噪算法(block clustering-nonlocal sparsity principal component analysis, BC-NLSPCA),通过对泊松噪声图像的稀疏表示与字典学习,准确高效区分有用信息与噪声信号,最大限度保留图像结构与细节特征,为后续图像分析奠定基础。

1 噪声模型与稀疏去噪算法

1.1 去噪模型

对于 $m>0$ 的整数,集合 $\{1, \dots, m\}$ 表示为 $[1, m]$ 。对于 $i \in [1, m]$, 设 y_i 为噪声图像的像素值。每个 y_i 是一个独立的随机泊松变量,其平均值 $f_i \geq 0$ 是要估计的去噪图像 f 的像素值。则每个 y_i 的离散泊松概率 P 为

$$P(y_i|f_i) = \frac{f_i^{y_i}}{y_i!} e^{-f_i} \quad (1)$$

设 Y 表示 $M \times N$ 的噪声图像, \hat{F} 定义为要估计的真实图像。 $Y_{i,j}$ 是 Y 中第 i 个补丁(图像块)中的第 j 个像素,去噪目标就是求出真实图像的估计值 \hat{F} 。 $\hat{F}_{i,j}$ 是 \hat{F} 中第 i 个补丁中的第 j 个像素,根据泊松噪声服从指数族分布的特性,用矩阵分解与字典学习方法得到去噪模型 $\hat{F}_{i,j}$ ^[11],如

$$\hat{F}_{i,j} \approx \exp([UV]_{i,j}) \quad \forall (i,j) \in [1, M] \times [1, N] \quad (2)$$

其中: U 为 $M \times l$ 系数矩阵; V 为字典组件的 $l \times N$ 矩阵, V 的行表示字典元素; l 为字典组件数目。

1.2 非局部 PCA 稀疏去噪算法

PCA 字典学习去噪算法主要通过对图像中的主成分进行分析,并对主成分分量进行字典表示,舍去非主成分部分,达到去噪的目的。非局部图像处理算法可避免图像的像素级运算,把图像分块后的图像块补丁当作处理目标进行整体去噪。

假设观察一个含噪声图像 $Y \in \mathbf{R}^{M \times N}$, 希望通过一些字典元素组件 $V = [v_1, \dots, v_l]$ 的组合近似估计真实图像 \hat{F} , 其中 U 是字典元素的权重,去噪的目标就是求 U 和 V 的最小化条件^[11],如

$$L(U, V) = \sum_{i=1}^M \sum_{j=1}^N \exp(UV)_{i,j} - Y_{i,j}(UV)_{i,j} + \lambda \text{Pen}(U) \quad (3)$$

其中 $\text{Pen}(U) = \sum_{i,j} |U_{i,j}|$, 是一个惩罚函数。通过参数 λ 控制数据拟合和稀疏性之间的权衡,求取 U 和 V 的最优解。

2 BC-NLSPCA 算法

采用非局部 PCA 稀疏去噪算法可直接对泊松噪声模型进行去噪,减少转换误差,但去噪后图像易模糊,影响图像质量。因此,对非局部 PCA 稀疏去噪算法进行改进,提出一种基于图像稀疏块表示和字典学习的泊松去噪(BC-NLSPCA)算法,以改善去噪后图像模糊现象,更好地保留图像细节信息。图1为BC-NLSPCA算

法的总体流程示意图。算法共分为四部分:分块处理,把图像分成宽度相同的 $n \times n$ 个相互重叠补丁;补丁聚类,将分块后的补丁用 Poisson K -均值法进行聚类;簇类去噪,将聚类后的每个簇分别运用非局部 PCA 稀疏去噪算法进行去噪处理;融合重建,将去噪后的补丁融合重建成完整去噪图像。

2.1 分块处理

图像分块的目的是避免图像像素级运算,不仅可提高运算速度,还能保证图像细节不被破坏。把 $M \times N$ 的图像分成大小相同的 $n \times n$ 重叠补丁,补丁大小跟去噪效果相关。令重叠部分长和宽分别为 h_1 和 h_2 ,当 M 可被 n 整除时 $h_1=0$,当 M 不能被 n 整除时 h_1 满足 $(\frac{M}{n} + 1)n - \frac{M}{n}h_1 = M$;当 N 可被 n 整除时 $h_2=0$,当 N 不能被 n 整除时 h_2 满足 $(\frac{N}{n} + 1)n - \frac{N}{n}h_2 = N$ 。文中根据相邻补丁的相似度确定补丁大小。余弦距离也称为余弦相似性,是用向量空间中两个向量夹角余弦值作为衡量两个个体间差异大小的量度。将补丁用行向量形式表示, \mathbf{a} 和 \mathbf{b} 代表两个相邻补丁行向量, $\mathbf{a} = (x_1, x_2, \dots, x_{n_2})$ $\mathbf{b} = (y_1, y_2, \dots, y_{n_2})$,则 \mathbf{a} 与 \mathbf{b} 的夹角余弦 $\cos \theta$ 为

$$\cos \theta = \frac{\sum_{i=1}^{n_2} (x_i y_i)}{\sqrt{\sum_{i=1}^{n_2} x_i^2} \sqrt{\sum_{i=1}^{n_2} y_i^2}} \tag{4}$$

余弦值越接近1,夹角越接近0,两个向量越相似。补丁宽度的选取非常重要,补丁越相似,聚类越准确,但补丁不能太小,否则会消耗较长时间。通过多次试验与分析得出 $\cos \theta = 0.02$ 左右时,去噪效果与运算效率能够达到最优平衡,由此获得自适应补丁宽度 n 。

2.2 补丁聚类

并非对每个图像块进行去噪处理,而是先对图像块补丁进行 Poisson K -均值聚类,后对每个簇进行去噪。使用低维字典稀疏表示每个簇数据,以提高字典计算效率。

使用手肘法确定最佳聚类数目 K 。手肘法的核心指标为误差平方和(sum of the squared errors, SSE),令 S 代表误差平方和, $S = \sum_{k=1}^K \sum_{f \in C_k} \|f - f_c(k)\|^2$, C_k 是第 k 个簇, f 是 C_k 中的补丁行向量, $f_c(k)$ 中的 c 代表聚类中心(center), $f_c(k)$ 是第 k 个簇的聚类中心, $k \in (1, 2, \dots)$, 误差平方和是聚类误差,代表聚类效果。手肘法的核心思想是随着聚类数的增大,样本划分会更精细,每个簇的聚合程度会逐渐提高,误差平方和相应逐渐变小。聚类数不能取无限大,因此可将拐点 K 值作为最佳聚类数,如图2所示。当聚类数小于 K 时,误差平方和的下降幅度较大;当聚类数到达 K 时,增加聚类数,误差平方和的下降幅度会骤减,然后趋于平缓。可见误差平方和与聚类数的关系呈手肘形状,肘部拐点对应的 K 为最佳聚类数目。

对于指数族, K -均值聚类算法可使用 bregman 散度进行推广,称为 bregman 聚类^[12],又称 Poisson K -均值聚类。bregman 散度 d 定义如下

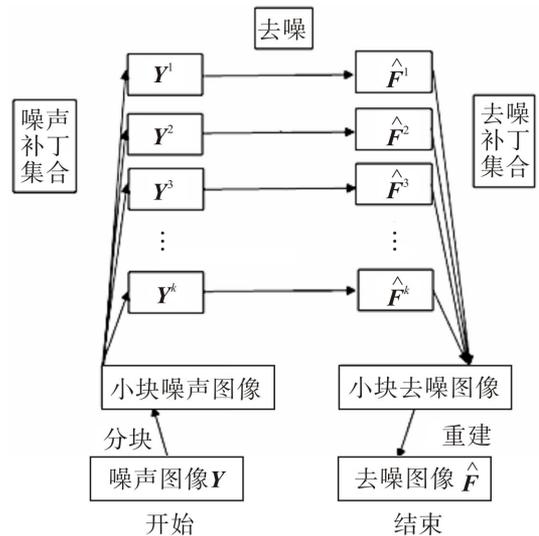


图1 BC-NLSPCA 算法总流程示意图

Fig. 1 General flow chart of BC-NLSPCA algorithm

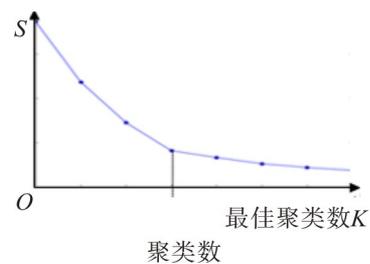


图2 S和聚类数的关系示意图

Fig. 2 Diagram of the relationship between S and cluster number

$$d(f, f_c(k)) = d(\log f, \log f_c) = \sum_j f_c(k)^j - f^j \log(f_c(k)^j) \quad (5)$$

把分块后的 $n \times n$ 补丁转化为 $1 \times n^2$ 的行向量, $j \in (1, 2, \dots, n^2)$ 。得到最佳聚类数 K , 再根据式(5)进行聚类, 聚类算法主要步骤如下:

- 1) 随机初始化 K 个补丁行向量作为聚类中心;
- 2) 根据式(5)计算图像每个补丁行向量到中心的距离, 将补丁行向量分配到距离最近的一个簇;
- 3) 针对每个聚类, 计算簇中所有补丁行向量的均值并将其作为新的中心;
- 4) 反复迭代, 当补丁行向量到最近簇距离不发生变化时停止计算, 返回 K 个聚类中心。

2.3 簇类去噪

每个簇内由个数不同的噪声补丁构成噪声图像矩阵 \mathbf{Y}^k , 令第 k 个簇有 W_k 个补丁。运用非局部PCA稀疏去噪算法对每个簇的噪声图像矩阵 \mathbf{Y}^k 去噪, 每个簇去噪后图像矩阵为 $\hat{\mathbf{F}}^k$ 。目标即是求 \mathbf{U} 和 \mathbf{V} 最小化条件 $L(\mathbf{U}, \mathbf{V})$, 如

$$L(\mathbf{U}, \mathbf{V}) = \sum_{i=1}^{M_k} \sum_{j=1}^{N_k} \exp(\mathbf{UV})_{ij} - \mathbf{Y}_{ij}(\mathbf{UV})_{ij} \quad (6)$$

M_k 和 N_k 分别为第 k 个簇噪声矩阵的长和宽, 根据文献[13-14]中的方法更新 \mathbf{U} 和 \mathbf{V} , 得到第 i 行 \mathbf{U}_{t+1} 的更新规则, 如

$$\mathbf{U}_{t+1,i,:} = \mathbf{U}_{t,i,:} - (\exp(\mathbf{U}_t \mathbf{U}_t)_{i,:} - \mathbf{Y}_{i,:}) \mathbf{V}_t^\top (\mathbf{V}_t \mathbf{D}_i \mathbf{V}_t^\top)^{-1} \quad (7)$$

其中 $\mathbf{D}_i = \text{diag}(\exp(\mathbf{U}_t \mathbf{V}_t)_{i,1}, \dots, \exp(\mathbf{U}_t \mathbf{V}_t)_{i,N_k})$, 是 $N_k \times N_k$ 的对角矩阵。更新 \mathbf{V}_{t+1} 的第 j 行规则为

$$\mathbf{V}_{t+1,:j} = \mathbf{V}_{t,:j} - (\mathbf{U}_{t+1}^\top \mathbf{E}_i \mathbf{U}_{t+1})^{-1} \mathbf{U}_{t+1}^\top (\exp(\mathbf{U}_{t+1} \mathbf{V}_t)_{:,j} - \mathbf{Y}_{:,j}) \quad (8)$$

其中 $\mathbf{E}_i = \text{diag}(\exp(\mathbf{U}_{t+1} \mathbf{V}_t)_{1,j}, \dots, \exp(\mathbf{U}_{t+1} \mathbf{V}_t)_{M_k,j})$ 是 $M_k \times M_k$ 的对角矩阵。

在字典系数矩阵 \mathbf{U} 的更新中增加稀疏性约束^[11], 确保舍去权重较小的字典元素, 保留重要字典元素描述每个噪声矩阵。最小化式(6)对 \mathbf{U} 施加稀疏性约束, 如

$$L^{\text{Pen}}(\mathbf{U}, \mathbf{V}) = L(\mathbf{U}, \mathbf{V}) + \lambda \text{Pen}(\mathbf{U}) \quad (9)$$

其中 $\text{Pen}(\mathbf{U})$ 是一个惩罚函数, 确保只使用稀疏字典元素表示每个噪声矩阵。参数 $\lambda = \text{Pen}(\mathbf{U}) = \sum_{i,j} |\mathbf{U}_{i,j}|$, 其控制数据拟合和稀疏性之间的权衡, 则字典元素 $\mathbf{U}_{t+1,:}$ 更新为

$$\mathbf{U}_{t+1,:} = \arg \min_{\mathbf{U} \in \mathbf{R}^R} \exp(\mathbf{UV}_t) \|1 - \mathbf{UV}_t\| \mathbf{Y}_{t+1,:} + \lambda \|\mathbf{U}\|_1 \quad (10)$$

根据文献[14], 获得以下更新规则

$$\begin{aligned} \mathbf{U}_{t+1,:} &= \arg \min_{z \in \mathbf{R}^R} \frac{1}{2} \|z - \gamma_t\|_2^2 + \lambda \|z\|_1 \\ \gamma_t &= \mathbf{U}_{t,:} - \nabla_{\mathbf{U}} f(\mathbf{U}_{t,:}) \end{aligned} \quad (11)$$

定义 $f(\mathbf{U}) = \exp(\mathbf{UV}_t) \|1 - \mathbf{UV}_t\| \mathbf{Y}_{t+1,:}$, 因此, 梯度 $\nabla f(\mathbf{U}) = (\exp(\mathbf{UV}_{t+1}) - \mathbf{Y}_{t+1,:}) \mathbf{V}_{t+1}^\top$, 得到问题(11)的解为

$$\mathbf{U}_{t+1,:} = \eta_{\text{st}}(\gamma_t, \lambda) \quad (12)$$

其中 η_{st} 是软阈值函数 $\eta_{\text{st}}(x, \tau) = \text{sign}(x)(|x| - \tau)_+$ 。当 $\|\exp(\mathbf{U}_t \mathbf{V}_t) - \exp(\mathbf{U}_{t+1} \mathbf{V}_{t+1})\|^2 / \|\exp(\mathbf{U}_t \mathbf{V}_t)\|^2 \leq \epsilon_{\text{stop}}$, 停止更新, ϵ_{stop} 为停止参数。

2.4 融合重建

参考图像融合重建方法^[15-16], 将去噪后的各图像补丁根据其分块前的原始坐标投影到原来位置。补丁块是重叠的, 对于重叠部分, 每个像素取重叠像素的平均值。该重建方法易于实现且时效快, 能够更好地实现从补丁空间到原始像素空间的重新投影, 减少由于补丁效应而产生的伪影。

3 实验结果与分析

实验PC机配置内存为4 GB,主频1.7 GHz,操作系统为win10 64位,软件设计平台为MATLAB 2016。选取三类微生物显微图像,分别是分辨率为 259×194 的Colpidium豆形虫图像、分辨率为 271×186 的Coleps榴弹虫图像和分辨率为 207×244 的Gastrotrich腹毛虫图像。三类图像目标与背景对比度低,且内部细节较为丰富。三类微生物标准图谱如图3。

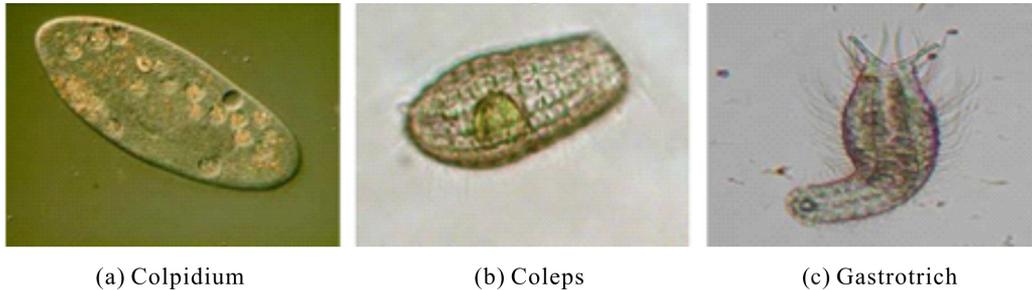


图3 微生物图谱

Fig. 3 Microbiological images

3.1 客观评价

衡量图像去噪效果的经典指标为峰值信噪比(peak signal to noise ratio, PSNR),其参量定义如下

$$\text{PSNR}(\hat{f}, f) = 10 \log_{10} \frac{255^2}{\frac{1}{M} \sum_j (\hat{f}_j - f_j)^2} \quad (13)$$

本文算法中的参数定义和取值如表1。

表1 算法参数

Tab. 1 Algorithm parameters

参数	定义	Colpidium取值	Coleps取值	Gastrotrich取值
n	补丁宽度	5	6	7
l	字典组件	4	4	4
K	聚类数	18	16	18
N_{iter}	迭代次数	20	20	20
$\varepsilon_{\text{stop}}$	停止参数	10^{-1}	10^{-1}	10^{-1}
$\varepsilon_{\text{cond}}$	调节参数	10^{-3}	10^{-3}	10^{-3}
λ	l_1 正则化参数	$70 \sqrt{\frac{\log W_k}{n}}$	$70 \sqrt{\frac{\log W_k}{n}}$	$70 \sqrt{\frac{\log W_k}{n}}$

文中选用不同等级噪声水平微生物图像进行对比实验。获取泊松噪声图像的方式为:将图像的最大亮度规范化为1,再将最大亮度调整到某一固定值,获取相应的泊松噪声污染图像,称此固定值为图像峰值(peak)。图像峰值越大,泊松噪声的强度越低。

与本文算法作效果对比的有均值去噪法^[17]、VST去噪法^[3]、NLSPCA去噪法^[11]等3种算法。均值去噪是典型的线性去噪算法,用模板中全体像素的平均值代替中心像素值,达到去噪目的;VST算法是将泊松噪声正向 Anscombe 变换成高斯噪声,对高斯噪声去噪,然后将去噪后的图像进行反向 Anscombe 变换;NLSPCA 算法将图像分块并聚类,再用 PCA 稀疏算法对聚类后图像进行去噪。表2为不同去噪算法的图像去噪 PSNR。从表2可看出,采用本文提出的BC-NLSPCA算法在不同测试图像种类以及相同种类微生物的不同噪声等级图像中,均获得了最高峰值信噪比,客观性能优于其他算法。这主要是因为采用本文算法直接处理泊松噪声结构可避免噪声结构转换带来的误差,并在分块和聚类步骤中进行改进,利用分块后相邻图片的相似性决定分块宽度;利用手肘法确定最佳聚类数 K ,再用 Poisson K -均值法进行聚类,大大提高了去噪图像的信噪比。

表2 不同去噪算法的图像去噪PSNR

Tab. 2 PSNR of denoising results of different denoising algorithms

测试图像	图像峰值	均值去噪算法	VST算法	NLSPCA算法	本文算法
Colpidium	1	13.29	21.25	22.19	24.95
	3	19.41	23.69	23.93	28.04
	5	20.88	24.04	24.29	29.07
	7	21.45	23.49	24.46	29.90
Coleps	1	11.53	23.30	23.70	24.93
	3	18.77	23.85	24.45	29.17
	5	20.15	24.87	25.34	30.90
	7	20.63	25.40	25.57	31.80
Gastrotrich	1	17.62	24.30	26.50	27.19
	3	20.34	24.97	26.69	30.37
	5	21.52	25.21	26.82	31.43
	7	22.48	25.39	26.94	32.27

3.2 主观评价

放大去噪图像的局部细节,观察噪声点的去除精度及图像细节和边缘信息保有度,定性评价去噪效果。图4~6为图像峰值为1,5噪声等级时,3种微生物显微图像不同去噪算法的去噪效果。

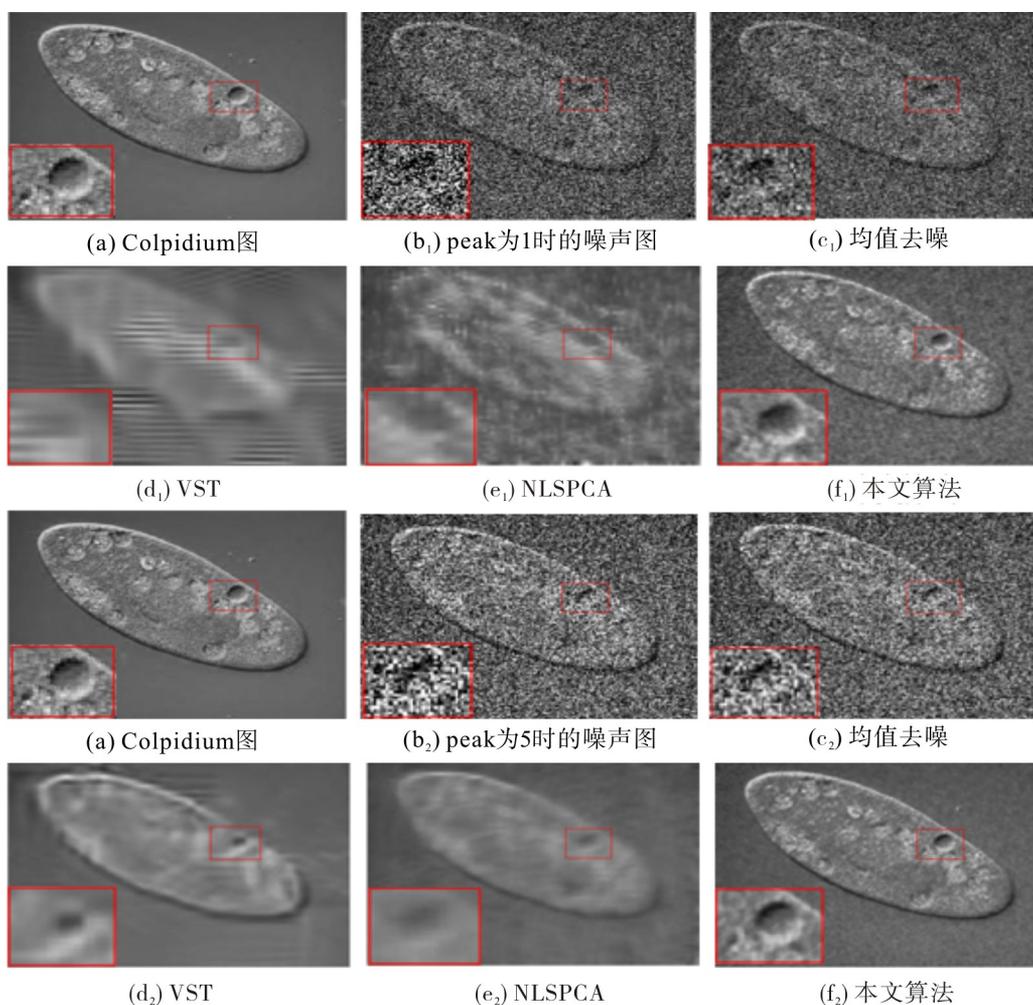


图4 图像峰值为1,5时各算法的Colpidium图像去噪结果

Fig. 4 Colpidium image denoising results of each algorithm when the image peak value is 1,5

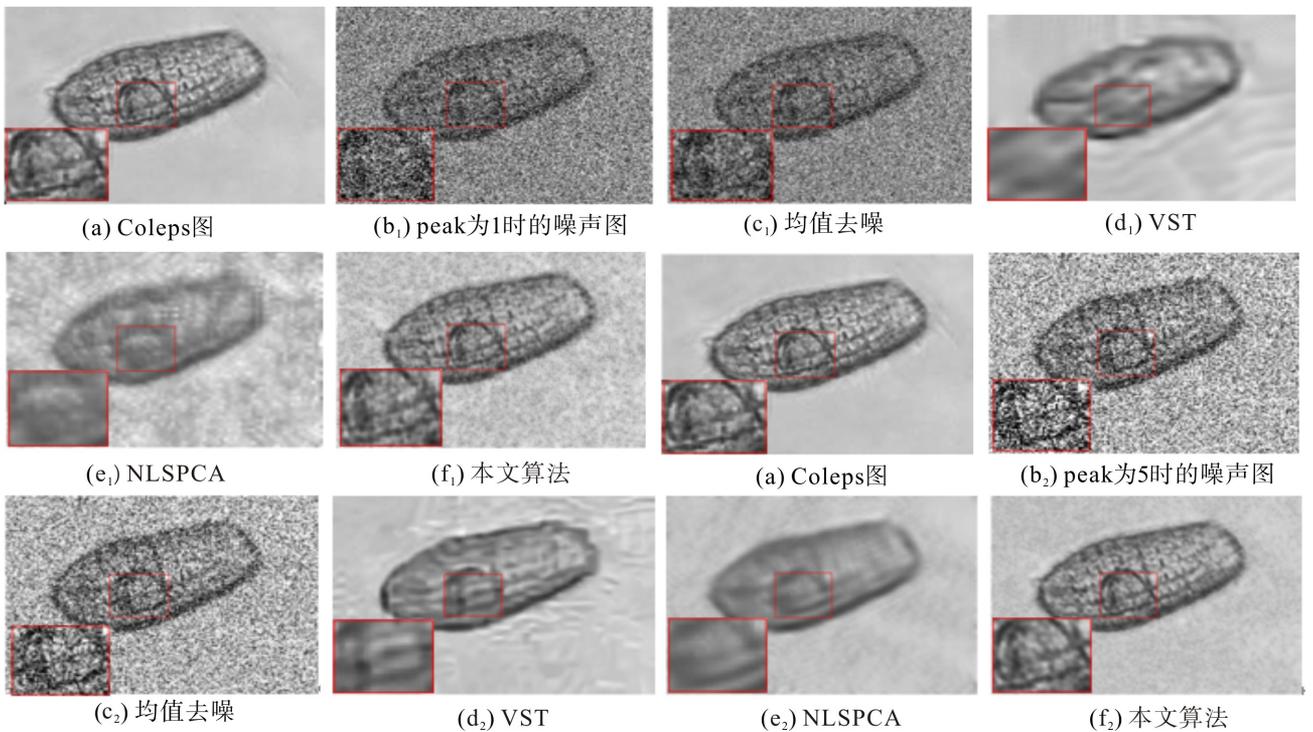


图5 图像峰值为1,5时各算法的Coleps图像去噪结果

Fig. 5 Coleps image denoising results of each algorithm when the image peak value is 1,5

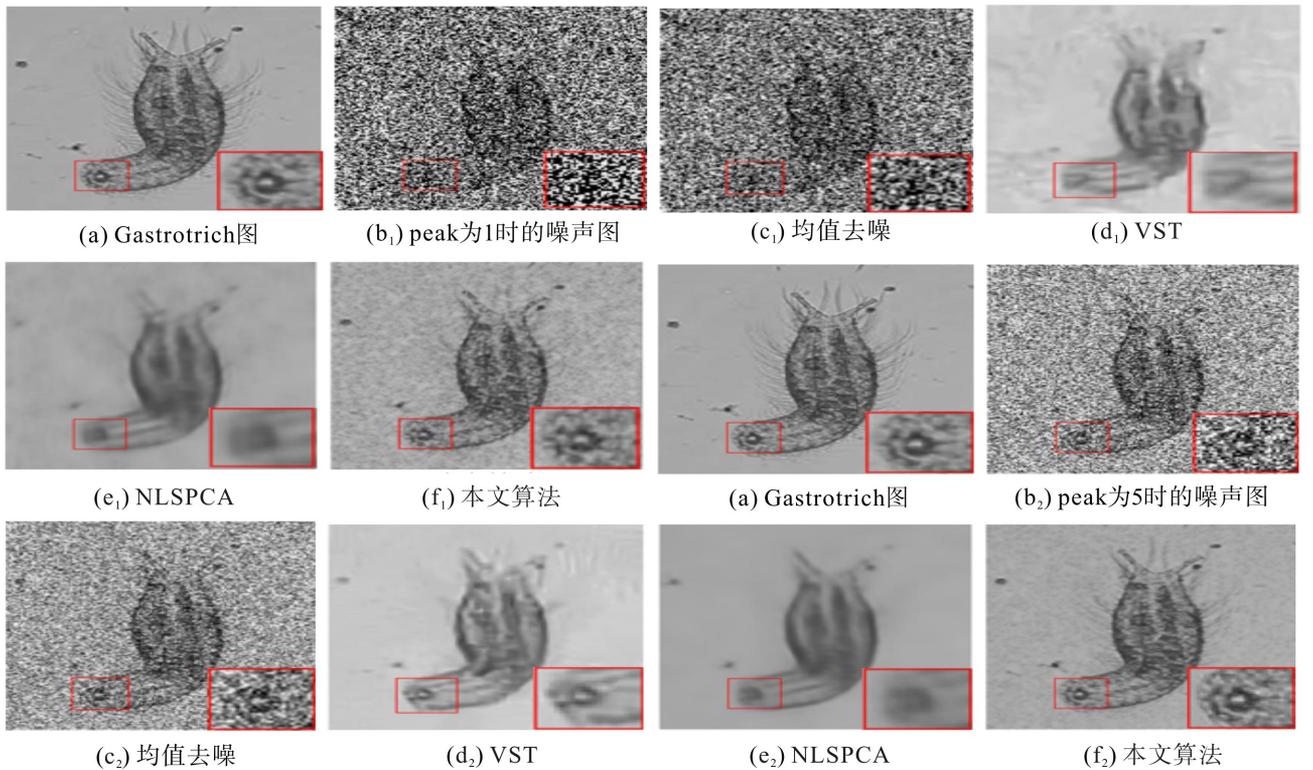


图6 图像峰值为1,5时各算法的Gastrotrich图像去噪结果

Fig. 6 Gastrotrich image denoising results of each algorithm when the image peak value is 1,5

观察图4~6的细节放大部分可见,与其他算法相比,采用本文算法去噪的微生物图像内部细节保留更好。从图像整体看:均值去噪算法对噪声点的去除情况不太理想;VST去噪产生了阶梯效应(块效应);NLSPCA算法由于分块的不自适应性导致去噪图像比较模糊,影响图像质量;本文BC-NLSPCA算法的去噪效果最

好,在高噪声(图像峰值为1)情况下更为明显。对于BC-NLSPCA算法,使用主成分分析的算法去噪,把噪声图像补丁看作一个目标像素块进行整体去噪,可较好地保护图像局部细节信息;运用图像内部自相关性选取合适的分块大小,大大改善了图像去噪后的模糊问题,获得了更好的去噪效果。

4 结 论

在泊松噪声模型框架下,利用指数族的推广,根据污水微生物显微图像的目标特征,提出一种基于图像分块聚类的非局部PCA稀疏泊松去噪算法。与传统图像去噪算法相比,本文算法可获取更高的图像信噪比,且在消除噪声的同时,可尽量多地保留细节信息,提高了去噪后微生物图像的画面质量,即使在噪声强度较高情况下也具较好表现。不足之处在于,算法用到了聚类 and 字典表示等多个步骤,运算速度略显逊色。如何在保留图像细节的同时进一步提高运行速度是今后的研讨方向。

参考文献:

- [1] 武治,孙照旋,周芳. 基于改进萤火虫算法的多阈值微生物图像分割[J]. 安徽工业大学学报(自然科学版),2020, 37(1):46-52, 59.
- [2] AZZARIL, FOIA. Variance stabilization for noisy+estimate combination in iterative Poisson denoising[J]. IEEE Signal Processing Letters, 2016, 23(8):1086-1090.
- [3] ZHANG MH, ZHANG F Q, LIU Q G, et al. VST-Net: variance-stabilizing transformation inspired network for Poisson denoising[J]. Journal of Visual Communication and Image Representation, 2019, 62:12-22.
- [4] 徐苏,周颖玥. 基于图像分割的非局部均值去噪算法[J]. 计算机应用, 2017, 37(7):2078-2083.
- [5] 曹硕,黄利萍,侯倍倍,等. 基于模糊边缘补足的自适应非局部均值图像去噪算法[J]. 激光与光子学进展, 2018, 55(1): 011003.
- [6] 张俊,马明溪,宁成臻,等. 分数阶整体变分泊松去噪模型的分裂Bregman方法[J]. 南昌工程学院学报, 2018, 37(4):57-60.
- [7] 张峥嵘,刘红毅,韦志辉. 欧拉弹性正则化的图像泊松去噪[J]. 电子学报, 2017, 45(1):181-191.
- [8] 汪浩然,夏克文,任苗苗,等. 结合PCA及字典学习的高光谱图像自适应去噪方法[J]. 计算机应用, 2016, 36(12):3411-3417, 3422.
- [9] XU J, ZHANG L, ZHANG D. External prior guided internal prior learning for real-world noisy image denoising[EB/OL]. 2017: arXiv:1705.04505[cs.CV]. <https://arxiv.org/abs/1705.04505>.
- [10] 印佳,杜战战. 基于主成分分析的高光谱遥感图像非局部去噪[J]. 现代电子技术, 2015, 38(11):70-72.
- [11] SALMON J, HARMANY Z, DELEDALLE C A, et al. Poisson noise reduction with non-local PCA[J]. Journal of Mathematical Imaging and Vision, 2014, 48(2):279-294.
- [12] BANERJEE A, MERUGU S, DHILLO N, et al. Clustering with bregman divergences[J]. J Mach Learn Res, 2005, 6:1705-1749.
- [13] ROY N, GORDON G, THRUN S. Finding approximate POMDP solutions through belief compression[J]. Journal of Artificial Intelligence Research, 2005, 23:1-40.
- [14] HARMANY Z F, MARCIA R F, WILLETT R M. This is SPIRAL-TAP: sparse poisson intensity reconstruction algorithms: theory and practice [J]. IEEE Trans Image Process, 2012, 21(3):1084-1096.
- [15] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8):2080-2095.
- [16] SALMON J, STROZECKI Y. Patch rejections for non local methods[J]. Signal Processing, 2012, 92(2):447-489.
- [17] 杨淑莹. 图像识别与项目实践: VC++、MATLAB技术实现[M]. 北京: 电子工业出版社, 2014:34-35.

责任编辑:何莉